

基于改进 YOLOv5s 的电力作业人员安全帽检测算法研究

刘昶成 邵文权 李玲陶

(西安工程大学电子信息学院 西安 710048)

摘要:传统的电力施工现场安全帽检测算法的网络计算复杂度高、在复杂场景下对于远处目标和密集群体存在漏检等问题,提出一种改进后的轻量化 YOLOv5s-GCAE 算法,主干网络首先用 GhostNet 网络中的深度可分离卷积 GhostConv,以此降低网络的计算量和参数量。其次在特征提取阶段中嵌入 CA 注意力机制,填补了引入轻量化网络时精度的缺失。引入自适应空间特征融合(ASFF)网络以有效融合多尺度特征,提高模型丰富的语义特征表示使网络更好的适应复杂的电力施工现场。最后引入损失函数 EIOU,促使网络专注于高质量的锚点以提升在复杂场景下安全帽检测精度。构建了一个包含开源图片和自行收集的图片共 9 326 张的安全帽佩戴检测数据集。实验结果表明,该算法的安全帽检测准确率为 93.4%,比 YOLOv5s 算法高 2.1%,符合电力场景下安全帽检测的精度要求。

关键词:安全帽检测;电力场景;YOLOv5s;CA 注意力模块;Ghost Net

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.2

Research on safety helmet detection algorithm for power operators based on improved YOLOv5s

Liu Changcheng Shao Wenquan Li Lingtao

(School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: The traditional network calculation complexity of the safety helmet detection algorithm at the power construction site is high, and there are problems such as missing detection for distant targets and dense groups in complex scenarios. This paper proposes an improved lightweight YOLOv5s-GCAE algorithm, in which the backbone network first uses the deep separable convolutional GhostConv in the GhostNet network to reduce the amount of computation and parameters of the network. Secondly, the CA attention mechanism is embedded in the feature extraction stage, which fills the lack of accuracy when introducing lightweight networks. The ASFF network is introduced to effectively fuse multi-scale features, improve the rich semantic feature representation of the model, and make the network better adapt to complex power construction sites. Finally, the loss function EIOU is introduced to promote the network to focus on high-quality anchor points to improve the accuracy of helmet detection in complex scenarios. In this paper, a safety helmet wearing detection dataset containing 9 326 open-source images and self-collected images is constructed. Experimental results show that the safety helmet detection accuracy of the algorithm is 93.4%, which is 2.1% higher than that of the YOLOv5s algorithm, which meets the accuracy requirements of safety helmet detection in power scenarios.

Keywords: helmet detection; power scenarios; YOLOv5s; CA attention mechanism; GhostNet

0 引言

随着我国新能源电力建设进入新的高峰期,现场管理

和安全规范方面存在的安全问题日益突出^[1],给作业人员带来不可预计的损害,其中安全帽佩戴不良行为造成事故数排在首位^[2]。据调查显示,大量电力工程现场每年都会

因为未佩戴安全帽、安全帽佩戴不规范而发生意外^[3]。

安全帽作为高效的防护工具,可以在发生危险事故时将头部受到的损伤最小化,以达到保护电网人员安全的目的。目前实际中的安全帽检测大多靠着人眼监督,可是持续高强度的人工监督极易让监管人员视觉疲劳从而做出误判,因此使用人工监督的监控方式已经落后于时代。为了解决人工检测效率低、成本高等问题,有效防止事故的发生,通过结合计算机视觉的目标检测技术则是更加高效快捷的。

国内外许多学者开始对安全帽检测开展研究,最早人们通过在安全帽上嵌入各类传感器,然后按照传感器信息检测工人是否佩戴安全帽。文献[4]在安防装备上应用了射频识别技术(radio frequency identification,RFID),并设计了移动射频识别装置。但是此检测对于外部设备的依赖性,使得该技术很难被实施。为了解决这一问题,基于机器学习的检测方法被提出。Dongmala 等^[5]结合了一种安全帽检测技术,首先使用了哈尔特征来检测安全帽区域,然后应用霍夫变换分别检测安全帽的全部和 $1/2$ ^[6]。相较于传感器检测,其避免了对设备的依赖性,但要手工设计特征,容易因复杂环境导致检测效果不佳,适应环境的泛化能力较差。

随着基于深度学习的发展,研究人员开始将机器学习和图像处理作为安全帽识别的应用技术。2014年,Girshick 等^[7-9]陆续提出了区域卷积神经网络(region-based CNN,R-CNN)、快速的基于区域的卷积神经网络(fast region-based CNN,Fast R-CNN)和更快速的基于区域的卷积神经网络(faster region-based CNN,Faster R-CNN)网络,并分别在 PASCAL VOC2007 数据集上进行验证,检测结果的实际效果将得到显著提升。这些模型还把自动提取特征框的方式从选择性搜索逐步变化到区域建议网络,从而摆脱了传统的手工提取特征方法。2015年,Redmon 等^[10]提出了一阶段检测模型(you only look once,YOLO),该网络模型首次将检测任务抽象为回归问题,避免了以往 R-CNN 系列回归模型中将检测任务拆分成两步走的复杂繁琐的操作。

文献[11]从背景干扰性方面角度考虑,对安全帽的实时检测进行分析,提出一种基于 YOLO 架构用于安全帽的实时检测。文献[12]将 YOLOv4 网络中的特征金字塔部分运用深度可分离卷积替换,获得具有多个不同多维尺度的特征数据的网络特征图,以此来降低模型体积。文献[13]在 YOLOv3 的基础上,加入多尺度自注意力机制;文献[14]在 YOLOv4 网络中引入卷积注意力模块(convolutional block attention module,CBAM)^[15]来增强对安全帽信息的获取。文献[16]针对安全帽尺寸不一的问题,在 YOLOv5s 网络中利用 K-means++ 算法,将已经设计好的模型先验框尺寸与其所对应的特征层进行匹配,再将多光谱通道注意力模块融入到特征提取网络,使其可以自主地学习各个通道的权重,但是由于增加了模型的参数,模

型的可移植性变的较差。文献[17]在 YOLOv5 的主干网络中添加坐标注意力机制,并且在特征融合模块加入加权双向特征金字塔网络结构,实现双向跨度尺度连接和加权特征融合。目前轻量化网络发展较为成熟,其中有 MobileNetV3 系列^[18]和 EfficientNetLite 系列^[19],旷世科技的 ShuffleNet 系列^[20],华为的 GhostNet^[21]等。文献[22-23]将 YOLOv5s 主干网络替换成 MobileNetV3 来进行特征提取,并与注意力机制结合的方式来实现轻量化的 YOLOv5s 研究,但对于检测平均精度却没有很好的顾及。文献[24]提出一种基于 YOLOv5s 的检测方法,使用 K-means 方法重新设计先验框的大小,在结构模型中加入小的目标检测层,最后又引入了注意力机制。

针对电力施工现场安全帽检测算法的网络计算复杂度高、远处小目标和密集群体存在漏误检等以及工程中需求实时性检测的问题,本文从 YOLOv5s 算法的基础上进行改进。主干网络首先用 GhostNet 网络中的深度可分离卷积 GhostConv,以此降低网络的计算量和参数量。在特征提取阶段中嵌入 CA 注意力机制,可以在一定程度上提高模型的特征表达能力,增强对小目标的信息获取能力,填补了引入轻量化网络时精度的缺失。引入自适应空间特征融合(ASFF)网络以有效融合多尺度特征,提高模型丰富的语义特征表示使网络更好的适应复杂的电力施工现场诸如变电站、电力生产建设等各类现场和工况。由于不同工作人员的脑部结构具有差异性,因此最后引入损失函数 EIOU,促使网络专注于高质量的锚点以提升在复杂场景下安全帽检测精度。多方面采取电力作业现场的数据集进行检测,在不影响检测速度的同时,有效的加快检测精度,使其在小目标和密集目标方面进一步提升检测效果。

1 YOLOv5 算法

YOLOv5 目标检测官方发布了 4 个网络模型,其网络模型可分为 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x。其中里面最基础的网络是 YOLOv5s,算法框架如图 1 所示。

1.1 输入端

输入端的信息主要为原始图像 RGB 三通道信息,包括马赛克增强、自适应计算锚、自适应缩放图像 3 个部分,经过随机缩放、随机裁剪、随机排布等方式对输入的图像进行拼接,Mosaic 图像数据增强将 4 张照片用随机方式排列和拼接出去的算法来进行图像数据的整合,从而使得新算法对小目标检测更加精准;YOLOv5s 会基于这些参数,开启一种自适应的锚框匹配计算,在各个类型的训练集中,计算出最优的真实锚框值,并且该网络基于原来的锚框输出一个预测框,然后对比预测框和每个真实框之间的差异,进而实现快速地对在该迭代网络上提取的图像参数信息进行逆向优化及更新处理,并且对图像数据也进行了前期的预处理,使得其处理效果将更能够显著并有利于图




图1 YOLOv5s 结构

像特征数据的提取。

1.2 主干网络

YOLOv5s 主干网络的构造主要由 CBS、CSP 和空间金字塔池化(SPPF)模块组成,CBS 模块是卷积模块、批量归一化模块和激活函数的组合,激活函数不再是 LeakyReLU,有利于加快模型推理速度。

1.3 Neck 模块

Neck 模块主要用于将主干提取的特征进行融合,其包括特征金字塔网络(FPN)和路径聚合网络(PAN),FPN 可以从上到下进行语义信息的传递,主要通过融合高层特征以此来提升对小目标物体的检测能力,PAN 是一种基于 FPN 改进的网络,PAN 在 FPN 的基础上增加了一个自下向上方向的路径,它可将低层的位置信息有效地传输到上层,从而实现对不同信息之间进行特征融合,进而进一步提升密集目标的检测能力,如图 2 所示。




图2 FPN 和 PAN 结构

1.4 输出端

在输出端,将 GIOU 函数作为边界框的损失函数,在目标检测后处理过程中,利用非极大值抑制来对多目标框进行筛选,通过降低交并比高的检测结果的分类得分来抑制冗余检测,旨在为每个检测目标保留一个检测结果,去除

那些多余的信息,从而增强多目标和遮挡目标的检测能力。

2 模型的改进和优化

2.1 引入轻量化 Ghost 网络

GhostNet 是由华为诺亚方舟实验室提出的,在卷积设计过程中,考虑到特征图层会出现大量的冗余信息,会对实验测评指标带来较大影响。因此尝试用更低复杂度的成本去获取这些冗余的特征图(feature map),如图 3 所示。




图3 卷积对比

图 3(a)为普通卷积的过程;图 3(b)为 GhostNet 处理的过程。在 Ghost 卷积中,首先选取部分特征图进行卷积操作,达到减少计算量的作用,然后使用 3×3 或 5×5 的卷积核进行逐通道卷积操作,最后将第 1 部分作为一份恒等映射,与第 2 步的结果进行 Concat 操作。GhostBottle-

neck 结构如图 4 所示。




图 4 GhostBottleneck 结构

1) $stride=1$, 不进行下采样, 直接进行两个 Ghost 卷积操作;

2) $stride=2$, 进行下采样, 多出来一个步长为 2 的深度卷积操作, 以降低特征图尺寸。

其卷积核心思想就是在少量的非线性的卷积得到的特征图的基础上, 再进行一次线性卷积, 以此实现网络模型的轻量化, 本文在主干网络中新融合一种 GhostSPFF 结构, 如图 5 所示。




图 5 Ghost SPFF

2.2 CA 注意力机制

注意力机制是一种来源于人脑处理视觉信息的方式, 在关注到重要特征的同时, 不仅可以抑制和去除不必要的其他特征, 又可以相应地转换图像中的空间信息以提取关键信息, 以此来增强了网络检测小目标的能力。实际电力施工现场大多为架空线路、变电站、电厂等, 考虑到复杂的背景因素会对安全帽这一小目标造成误检从而影响检测精度, 因此本文添加了注意力机制来缓解这一问题。CA 注意力机制如图 6 所示。

CA 自注意力机制通过精确的位置信息对通道关系和




图 6 CA 模块结构

长期依赖性进行编码, 由 Coordinate 信息嵌入和 Coordinate 注意力生成组成:

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq j < W} x_c(h, j) \quad (1)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq i < H} x_c(i, w) \quad (2)$$

式中: z_c 为第 c 个通道输出的编码值; w 和 h 为图像的宽和高。对尺寸为 $C \times H \times W$ 输入特征图 Input 分别按照 X 方向和 Y 方向进行池化, 分别生成尺寸为 $C \times H \times 1$ 和 $C \times 1 \times W$ 的特征图。

对模块生成的两个特征图同时进行一个共享 1×1 卷积的变化, 然后进行 Concat 操作:

$$f = \delta(F_1([z^h, z^w])) \quad (3)$$

式中: $f \in R^{C/r \times (H+W)}$ 沿着空间维度, 再将 f 进行拆分操作, 生成两个独立的张量 $f^h \in R^{C/r \times H}$ 和 $f^w \in R^{C/r \times W}$, 再分别利用两个 1×1 的卷积操作统一通道数, 再结合 sigmoid 激活函数的到最后的注意力向量。

$$g^h = \sigma(F_h(f^h)) \quad (4)$$

$$g^w = \sigma(F_w(f^w)) \quad (5)$$

最后关于 g^h 和 g^w 输出如下:

$$y_c(i, j) = x_c(i, j) \times g^h(i) \times g^w(j) \quad (6)$$

在特征提取阶段, 本文将在 GhostConv 模块中引入了 CA 注意力机制模块, 如图 7 所示, 来加强位置信息与安全帽特征的关联程度, 从而提高安全帽在复杂环境下的识别能力。

2.3 ASFF 的融合

为了使得模型在特征融合阶段能够更好进行语义信息的深浅融合, 不同于以往基于元素和的方法或级联的多




图7 Ghost CA融合

层次特征融合的方法,现融入自适应特征融合机制,解决FPN中多尺度预测时特征层预测目标不一致的问题,提高FPN形式的模型性能,为了不增加轻量化模型的大小,在特征融合阶段使用两层ASFF,在输出的第1的第3引入ASFF,进一步的加强特征提取,如图8所示。




图8 ASFF融合

ASFF使用的是学习对不同语义信息进行权重的融合:

$$y_{ij}^1 = \alpha_{ij}^1 \otimes x_{ij}^{1 \rightarrow 1} + \beta_{ij}^3 \otimes x_{ij}^{3 \rightarrow 1} \quad (7)$$

式中: α_{ij}^1 、 β_{ij}^3 为来自不同层的权重; $\otimes$ 是卷积操作; $x_{ij}^{1 \rightarrow 1}$ 、 $x_{ij}^{3 \rightarrow 1}$ 为来自不同特征图的输出。第1层特征图的方式是 y_{ij}^1 , 采用相加的方式。并且保证 $\alpha_{ij}^1 + \beta_{ij}^3 = 1$, 因此最后的 α_{ij}^1 如下:

$$\alpha_{ij}^1 = \frac{e^{\alpha_{ij}^1}}{e^{\alpha_{ij}^1} + e^{\beta_{ij}^3}} \quad (8)$$

2.4 损失函数的改进

在输出端中,损失函数会对模型进行优化,从而判断预测数据和期望数据之间的差异,引入的损失函数采用

EIOU, EIOU_Loss 包括 3 个部分, 分别为交并比 (IOU) 损失、距离损失、高宽损失。

$$L_{EIOU} = L_{IOU} + L_{dis} + L_{asp} = 1 - IOU + \frac{\rho^2(b, b^{gt})}{(w^c)^2 + (h^c)^2} + \frac{\rho^2(w, w^{gt})}{(w^c)^2} + \frac{\rho^2(h, h^{gt})}{(h^c)^2} \quad (9)$$

式中: w^c 、 h^c 是预测边界框与真实边界框的最小外接矩形的宽度和高度。 ρ 是两点之间的欧氏距离, 将纵横比的损失项拆分成预测的高度之后, 分别与最小外接框宽高的差值, 加速了收敛提高回归精度。

3 实验与分析

3.1 数据收集

由于目前还没有电力施工现场的基准数据集, 因此本文通过从网络爬虫截取、开源数据集、自行实景收集的途径中收集图片, 其中包含了不同光照、不同颜色、不同分辨率的图像共 9 326 张, 往数据集中放入了一些不同的礼帽、草帽、太阳帽等干扰物, 并将其划分为“person”类别, 以此来提升模型对于干扰物的泛化性。

为了避免在目标检测的训练的过程中, 数据因为过少而存在过拟合现象, 导致精度振荡过大。因此本文通过对部分图片进行增强亮度、对比度增强、水平翻转和随即方向旋转, 本文采用先划分数据集, 后扩充, 以此避免因为扩充的数据集重复性过高导致精度不准确的问题。最后通过 LabelImg 软件对所收集照片进标注, 格式为 XML 格式, 本文数据集内的标注被分成“hat”和“person 两类。”

3.2 实验环境

实验采用 Pytorch 学习框架搭建, 训练所用硬件平台配置如表 1 所示。

表 1 实验环境

类别	参数
GPU	i7-11700
内存	32 GB
CUDA	11.1
Python	3.8
Pytorch	1.9.1

3.3 衡量标准

本文采用召回率 (recall, R)、平均精度 (AP)、平均精度均值 (mAP)、以及检测速度作为检测的评价指标, mAP 越趋向于 1, 代表该模型越趋向最优模型。P-R 曲线是以精度 P 为纵轴、召回率 R 为横轴的二维曲线。其中, TP 表示标签为正, 预测为正的样本数量; FP 标识标签为负, 预测为正的样本数量; FN 表示标签为正, 预测为负的样本数量。 R 取值越大表示模型真实情况为正例中预测正例的占比越大。

平均精度代表是 PR 曲线围成起来阴影部分的面积:

$$AP = \int_0^1 P(R) dR \quad (10)$$

精确度代表着是正样本并且分配正确的样本占所有分类器认定是正样本的比例:

$$P = \frac{TP}{TP + FP} \quad (11)$$

召回率代表着是正样本并且确实是正类的部分占所有确实是正类的比例:

$$R = \frac{TP}{TP + FN} \quad (12)$$

IOU 是计算 mAP 的重要函数:

$$IOU = \frac{A \cap B}{A \cup B} \quad (13)$$

式中: A 为预测的边框; B 为真实的边框。

3.4 消融实验

本文为了验证融合的模块各自对于模型性能的影响,以 YOLOv5s 模型为基准,在相同的配置条件下使用相同数量的测试集,实验结果以 mAP@0.5 来进行评价,消融实验的对比如图 9 所示,可以看出,改进后的 YOLOv5s-GCAE 模型是最优的曲线。

消融实验结果如表 2 所示,✓ 表示模型的混合改进,原始 YOLOv5s 的精确率为 91.3%。以此为基准,除了引




图9 消融实验 mAP 曲线对比

入 Ghost 模块会略微降低精确度之外,其他模块都提升了精度;通过 Ghost 模块逐层卷积之后,虽然在平均精度上下降了 0.4%,但是让参数量减少了 8.35 MB,检测时间也减少了 1.4 ms;CA 注意力机制的引入仅使得参数量增加 0.1 MB 的同时精度提升了 0.8%;加入 ASFF 参数量之后,导致参数量增加,但精度提升了 0.6%;优化损失函数之后参数量不变,但精度提升了 0.5%。综合来看本文将 4 处改进措施融合的 YOLOv5s-GCAE 效果最优,使得模型精度在提升 2.1% 的同时,保持良好的实时性。进一步验证了改进方案的可行性。

表2 YOLOv5s 消融实验对比

Ghost	CA	ASFF	EIoU	FLOPS	参数/MB	mAP/%	时间/ms
				16.0	13.7	91.3	6.6
✓				6.3	5.45	90.9	5.2
	✓			16.0	13.8	92.1	7.5
		✓		21.6	22.4	91.9	7.8
			✓	16.0	13.7	91.8	6.6
✓	✓		✓	6.4	5.53	91.3	7.4
✓		✓	✓	11.9	14.0	91.6	7.9
✓	✓	✓	✓	11.9	14.1	93.4	6.9

3.5 与其他算法对比

为了进一步衡量本文提出的算法在安全帽检测方向中的性能。在训练中,将迭代轮数设置为 200 轮,将本文提出的算法在其他相同配置下,将与单阶段网络 YOLOv3、YOLOv3-tiny、YOLOv4、YOLOv5s、YOLOv5m、YOLOv5l、YOLOv7、SSD 算法与 Faster R-CNN 网络一起训练 200 轮进行比对。改进后的模型为黄色曲线,实验对比如图 10 所示。

前 50 轮几种模型训练效果良好,均没有出现过拟合和欠拟合的现象,改进之后的模型在平均精确率方面相较于其他模型均有了显著的提升,由此验证了改进方法的可行性。实验对比结果如表 3 所示。

图 11 所示为改进模型的混淆矩阵图,本文在数据集中选取了部分测试图像,共 200 张,813 个目标,经过测试,各网络模型的漏检率、漏检数、误检率和误检数如表 4




图10 与其他主流算法 mAP 曲线对比

所示。

从表 4 可以看出,在参考同样本的情况下,本文提出的模型在漏检率和误检率均为最低,分别只有 2.1% 和 2.9%。

表 3 与主流算法性能对比的实验结果

检测模型	$P/\%$	$R/\%$	mAP/%	模型/MB	FLOPS	时间/ms
YOLOv3	91.8	86.9	92.3	117	154.6	27.9
YOLOv3-tiny	87.1	76.3	83.8	16.6	12.9	5.7
YOLOv4s-mish	90.8	85.4	91.4	105	20.6	12.1
YOLOv5s	90.3	84.7	91.3	13.7	16.0	6.6
YOLOv5m	92.5	85.6	91.9	40.2	49.2	12.1
YOLOv5l	89.4	87.4	91.9	88.4	109.6	22.7
改进 YOLOv5s	92.3	86.4	93.4	14.1	11.9	6.9
YOLOv7	90.8	85.0	90.6	71.3	106.5	22.9
Faster R-CNN	90.5	86.5	90.5	316.6	91.0	61.8
SSD	89.8	87.0	90.0	188.2	129.8	23.7




图 11 混淆矩阵图

表 4 测试结果

模型	漏检率/%	漏检数	误检率/%	误检数
YOLOv3	9.7	78	10.2	83
YOLOv3tiny	12	90	14.6	118
YOLOv4-mish	6.5	52	7.4	60
YOLOv5s	3.2	83	5.5	44
YOLOv5m	3.7	30	4.6	37
YOLOv5l	2.8	22	5.9	47
YOLOv7	3.5	28	4.9	39
本文	2.1	17	2.9	23

3.6 检测结果对比

为了进一步说明改进算法的检测性能,本文在测试集上进行了目标检测实验。不同场景下的检测结果对比如图 12 所示,图 12(a)是在对于远距离小目标人员检测;图 12(b)是对密集目标人员安全帽的检测;图 12(c)是对自然场景下存在背景干扰的人员安全帽检测;图 12(d)是对于弱光照下人员安全帽的检测;在前 3 种场景下,改进后的模型检测性能都优于原模型,在弱光照检测下,可以看出原模型存在漏检,而改进后的模型没有出现漏检,这是因为原模型在特征提取的时候,安全帽存在部分信息丢




图 12 模型改进前后检测结果对比

失,因此本文提出的算法在 GhostConv 卷积中嵌入 CA 注意力机制,可以在一定程度上提高模型的特征表达能力,增强对小目标的信息获取能力,同时引入 ASFF 网络以有效融合多尺度特征,提高模型丰富的语义特征表示使网络更好的适应复杂的电力施工现场;对比效果表明,本文提

出的 GCAE-YOLOv5s 的检测效果优于原模型,达到了需要的效果。

4 结 论

本文针对电力作业人员安全帽检测任务,对 YOLOv5s 网络进行了改进,主干网络首先用 GhostNet 网络中的深度可分离卷积 GhostConv,以此降低网络的计算量和参数量;其次在特征提取阶段中嵌入 CA 注意力机制,填补了引入轻量化网络时精度的缺失,增强模型的感受野;再引入 ASFF 网络以有效融合多尺度特征,提高模型丰富的语义特征表示使网络更好的适应复杂的电力施工现场;最后引入损失函数 EIOU,促使网络专注于高质量的锚点以提升在复杂场景下安全帽检测精度。满足在危险系数过高、安全隐患较多的电力施工现场下对安全帽佩戴检测的需求,在推理时间略微上涨的情况下,达到了比原模型精度提高 2.1% 的效果。目前本文在弱光照检测下存在部分精度下降,后续会加强这方面的改进,将在不降低模型精度的前提下尽可能的降低模型参数量,进一步提升模型的检测性能。

参 考 文 献

- [1] 张海雄. 电力人身伤亡事故防范对策和措施[J]. 科技创新与应用, 2014 (30): 170-171.
- [2] 田水承, 刘芬, 杨禄, 等. 基于计划行为理论的矿工不安全行为研究[J]. 矿业安全与环保, 2014, 41(1): 109-112.
- [3] 屈文谦, 邱志斌, 廖才波, 等. 基于 YOLOv3 的电网作业人员安全帽佩戴检测[J]. 中国安全生产科学技术, 2022, 18(2): 214-219.
- [4] KELM A, LAUBAT L, MEINS-BECKER A, et al. Mobile passive radio frequency identification (RFID) portal for automated and rapid control of personal protective equipment (PPE) on construction sites[J]. Automation in Construction, 2013, 36: 38-52.
- [5] DOUNGMAHA P, KLUBSUWAN K. Helmet wearing detection in Thailand using Haar like feature and circle hough transform on image processing[C]. 2016 IEEE International Conference on Computer and Information Technology (CIT). IEEE, 2016: 611-614.
- [6] PHUC L T H, JEON H, TRUONG N T N, et al. Applying the Haar-cascade Algorithm for detecting safety equipment in safety management systems for multiple working environments [J]. Electronics, 2019, 8(10): 1079.
- [7] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. IEEE Computer Society, 2014: 580-587.
- [8] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [9] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (6): 1137-1149.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Computer Vision & Pattern Recognition. IEEE, 2016: 779-788.
- [11] 丁田, 陈向阳, 周强, 等. 基于改进 YOLOX 的安全帽佩戴实时检测[J]. 电子测量技术, 2022, 45(17): 72-78.
- [12] 彭继慎, 孙礼鑫, 王凯, 等. 基于模型压缩的 ED-YOLO 电力巡检无人机避障目标检测算法[J]. 仪器仪表学报, 2021, 42(10): 161-170.
- [13] 李振华, 张雷. 改进 YOLOv3 的安全帽佩戴检测方法[J]. 国外电子测量技术, 2022, 41(12): 148-155.
- [14] 王雨晨, 徐明昆. 基于改进 YOLOv4 的安全帽佩戴检测算法[J]. 现代信息科技, 2021, 5(22): 156-160, 164.
- [15] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [16] 张锦, 屈佩琪, 孙程, 等. 基于改进 YOLOv5 的安全帽佩戴检测算法[J]. 计算机应用, 2022, 42(4): 1292-1300.
- [17] 王玲敏, 段军, 辛立伟. 引入注意力机制的 YOLOv5 安全帽佩戴检测方法[J]. 计算机工程与应用, 2022, 58(9): 303-312.
- [18] BILANG J M D, BALBUENA P A A L, VILLAVERDE J F. Cactaceae detection using MobileNet architecture [C]. 2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNI-CEM), 2021: 1-5.
- [19] KURIAKOSE B, SHRESTHA R, SANDNES F E. SceneRecog: A deep learning scene recognition model for assisting blind and visually impaired navigate using smartphones [C]. 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2021: 2464-2470.
- [20] FAN Z, HU W, GUO H, et al. Hardware and algorithm co-optimization for pointwise convolution and channel shuffle in ShuffleNetV2[C]. 2021 IEEE International Conference on Systems, Man, and

- Cybernetics (SMC), 2021: 3212-3217.
- [21] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [22] 杨永波, 李栋. 改进 YOLOv5 的轻量级安全帽佩戴检测算法[J]. 计算机工程与应用, 2022, 58(9): 201-207.
- [23] 张银胜, 杨宇龙, 吉茹, 等. 改进 YOLOv5s 的风力涡轮机表面缺陷检测[J]. 电子测量与仪器学报, 2023, 37(1): 40-49.
- [24] ZHANG Y J, XIAO F S, LU Z M. Helmet Wearing state detection based on improved YOLOv5s [J]. Sensors, 2022, 22(24): 9843.

作者简介

刘昶成, 硕士研究生, 主要研究方向为计算机视觉、现代电力系统控制与保护等。
E-mail: 1073826504@qq.com